

für A'im

88/2588

19) BUNDESREPUBLIK
DEUTSCHLAND



DEUTSCHES
PATENTAMT

12) **Offenlegungsschrift**
10) **DE 44 22 545 A 1**

51) Int. Cl. 6:
G 10 L 5/06

B1

21) Aktenzeichen: P 44 22 545.8
22) Anmeldetag: 28. 6. 94
43) Offenlegungstag: 4. 1. 96

71) Anmelder:
Alcatel SEL AG, 70435 Stuttgart, DE

72) Erfinder:
Hörmann, Thomas, Dipl.-Ing. (BA), 71723
Großbottwar, DE; Rozinaj, Gregor, Dr.-Ing., 70191
Stuttgart, DE

56) Für die Beurteilung der Patentfähigkeit
in Betracht zu ziehende Druckschriften:

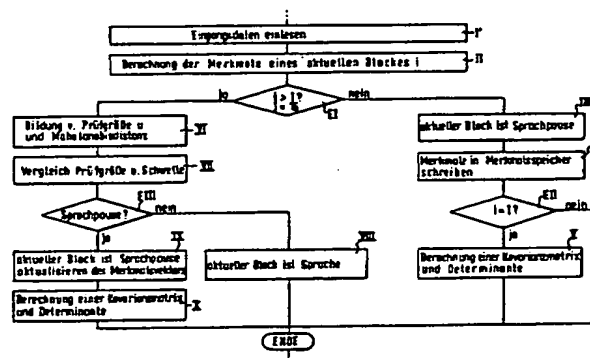
DE 37 39 681 A1
DE 34 22 877 A1
WO 86 03 047

DE 44 22 545 A 1

BEST AVAILABLE COPY

54) Start-/Endpunkt-Detektion zur Worterkennung

57) Bei der Spracherkennung zur Erkennung von Worten muß eine exakte und in bezug auf Geräusche robuste Detektion von Start-/Endpunkten der Worte, auch bei stark geräusch-behafteter Umgebung, gewährleistet sein. Verwendung eines weiteren Merkmales mit geräuschrobus-ten Eigenschaften.
Für einen Merkmalsvektor wird als erstes Merkmal eine Funktion der Signalenergie gebildet und als weiteres Merk-mal eine Funktion der quadratischen Differenz eines LPC (Linear-Predictive-Coding)-Cepstrum Koeffizienten. Daraus wird eine Prüfgröße oder eine Maximumfunktion einer Verteilungsfunktion berechnet, die im Vergleich mit einer Schwelle Start- und Endpunkte detektieren.



DE 44 22 545 A 1

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen

BUNDESDRUCKEREI 11. 95 508 061/378

15/27

Beschreibung

Die Erfindung betrifft ein Verfahren zur Erkennung von sowohl Sprache als auch Sprachpausen für die Spracherkennung. Im speziellen betrifft die Erfindung die Detektion von Startpunkten und Endpunkten von

Worten bei der Spracherkennung. Die Detektion von Startpunkten und Endpunkten von Worten ist für die Spracherkennung und für eine hohe Erkennungsrate ein wesentliches, zu lösendes Problem. Grundsätzlich erfolgt eine Start-/Endpunkt-Detektion so, daß in einem vorgegebenen Zeitintervall die Energie berechnet wird. Liegt die berechnete Energie oberhalb einer ebenfalls festgelegten Schwelle, liegt Sprache, also ein Wort vor. Ist die Energie unterhalb einer Schwelle, liegt eine Sprachpause vor. Mittels diesem Energievergleich kann also angegeben werden, wo sich ein Wortanfang und ein Wortende befindet.

Diese Verfahren arbeiten aber nur solange zuverlässig, als daß keine oder nur sehr gleichmäßig auftretende Geräusche als Hintergrundgeräusche auftreten. Falls sehr gleichmäßig auftretende Geräusche auftreten, muß die Schwelle aber einstellbar sein. Bei gleichmäßig lauten Hintergrundgeräuschen wird die Schwelle erhöht, damit Sprachpausen nicht als Sprache erkannt werden.

Hierbei treten aber für genau den Fall Probleme auf, bei dem das Signal/Rauschverhältnis sehr klein ist, weil für diesen Fall der energetische Unterschied zwischen Sprache und Pause nur sehr gering ist. Aufgrund dieser Probleme wurden "Adaptive Systeme zur Reduktion von Umgebungsgeräuschen bei Sprachübertragung" entwickelt, die unter Verwendung weiterer Merkmale, wie z. B. der Nulldurchgangsrate, eine bessere Sprach/Pausen-Detektion durchführen (aus: "Adaptive Systeme zur Reduktion von Umgebungsgeräuschen bei Sprachübertragung" Dissertation von Werner Reich, Universität Fredericana Karlsruhe, Februar 1985, S. 76—95).

Desweiteren ist in dem Stand der Technik ebenfalls erläutert, sowohl die mittlere Leistung, als auch die Nulldurchgangsrate zur Bildung der Merkmalsvektoren heranzuziehen, danach eine Merkmalsstatistik durchzuführen, und diese mit einem Schwellwert zu vergleichen (Abschlußbericht zum Verbundforschungsvorhaben, "Erkennung und Verarbeitung von gesprochener Sprache mit einfacher Syntax und Semantik für Informations- und Leitsysteme", Kapitel 2.2 Pausendetektor; Universität Fredericana Karlsruhe 24.11.1989).

Diese beiden letztgenannten Methoden sind in ihrer Ausführung sehr rechenintensiv.

Es ist Aufgabe der Erfindung ein Verfahren zur Start-/Endpunkt-Detektion vorzusehen, daß die Start- und Endpunkte von Worten detektiert, unabhängig von den Umgebungsgeräuschen.

Die Aufgabe wird erfindungsgemäß gelöst durch die Lehre der Ansprüche 1 und 6.

Ein Vorteil der Erfindung liegt darin, daß bei häufig wechselnden Umgebungsgeräuschen, aber auch bei ständig gleichen Umgebungsgeräuschen, bei denen das Signal/Rauschverhältnis sehr klein ist, dennoch eine exakte Detektion der Start-/Endpunkte stattfindet, was für eine hohe Erkennungsrate von Worten notwendig ist.

Ein weiterer Vorteil ist, daß das erfindungsgemäße Verfahren weniger rechenaufwendig ist, als bisher übliche Verfahren und daß der benötigte Speicherplatz sich signifikant verringert.

Weitere vorteilhafte Ausgestaltungen sind den Unteransprüchen 2 bis 5 und 7 bis 8 zu entnehmen.

Vorteilhaft ist, daß bei einem schlechten Signal/Rauschverhältnis, durch eine höhere Bewertung des zweiten Merkmals eine noch bessere Start-/Endpunkt-Detektion erfolgt, so daß die Erkennungsrate sich noch mehr erhöht.

Im folgenden wird die Erfindung anhand von Ausführungsbeispielen mittels Figuren näher erläutert. Folgende Figuren zeigen:

Fig. 1 Blockschaltbild eines Verfahrens nach Anspruch 1,

Fig. 2 Blockschaltbild eines Verfahrens nach Anspruch 6.

Im folgenden wird ein Ausführungsbeispiel (ohne Figur) erläutert, bei dem insgesamt $N = 2$ unterschiedliche Merkmale einen Merkmalsvektor bestimmen. In dem Ausführungsbeispiel ist die Anzahl der Abtastwerte pro Block $L = 160$. Die Anzahl der sich in einem Speicher befindenden Merkmale ist gleich $I = 16$.

Der Merkmalsvektor c für einen aktuellen Block $i = 0, 1, 2, \dots$ lautet

$$c(i) = \begin{bmatrix} ZCR(i) \\ BMW(i) \end{bmatrix} \quad (1)$$

Der Merkmalsvektor $c(i)$ besteht aus $ZCR(i)$, das sich folgendermaßen zusammensetzt. Für jeden Block werden vorzugsweise $K = 10$ LPC (Linear-Predictive-Coding)-Cepstrum-Koeffizienten errechnet. Hierbei ist die Anzahl $K = 10$ eine erfahrungsgemäß gut geeignete Anzahl, kann aber sowohl größer als auch kleiner gewählt werden. Die LPC-Cepstrum-Koeffizienten werden von nun an folgendermaßen abgekürzt.

$$CEP(n) \quad (2)$$

für $n = 0, \dots, K-1$, mit $K = 10$.

Die LPC-Cepstrum-Koeffizienten der letzten, zeitlich zuvor ermittelten Werte werden in einem Speicher gespeichert. Der Speicher speichert z. B. die $H = 4$ letzten, während einer Pause ermittelten Werte.

Demnach ergibt sich

CEP(m, n) (3)

für

m 0...H-1, mit H = 4,

n = 0...K-1 mit K = 10.

5

Ein mittlerer LPC-Cepstrum-Koeffizient der für ein Pausensignal errechnet wird, errechnet sich mit den Werten die in dem Speicher gespeichert sind zu:

10

$$CEP_{\text{AVER}}(n) = \frac{1}{H} \sum_{m=0}^{H-1} CEP(m, n) \quad (4)$$

15

Demnach errechnet sich das Merkmal ZCR(i) des Merkmalsvektors c(i) folgendermaßen:

$$ZCR(i) = \sum_{n=0}^{K-1} [CEP(n, i) - CEP_{\text{AVER}}(n)]^2 \quad (5)$$

20

Also ist ZCR(i) die Differenz des LPC-Cepstrum-Koeffizienten des aktuellen Blockes i gegenüber dem mittleren LPC-Cepstrum-Koeffizienten, und dies zum Quadrat. In der Gleichung (5) gilt

25

CEP(n, i) (5a)

für

i = aktueller Block,

n = 0...K-1 mit K = 10.

30

Das zweite Merkmal BMW(i) des Merkmalsvektors c(i) ist eine Funktion der Signalenergie. Genauer gesagt ist BMW(i) die mittlere Leistung und berechnet sich:

35

$$BMW(i) = \frac{1}{L} \sum_{k=0}^{L-1} |x| (k, i) \quad (6)$$

40

mit L = 160 und i gleich dem aktuellen Block.

Im weiteren Verfahren wird ein Schätzwert für den Mittelwert der Merkmale \hat{mp} berechnet. Dieser bestimmt sich in Abhängigkeit von I, der, wie zuvor bereits beschrieben, Anzahl der im Speicher gespeicherten Merkmale. Hierbei gibt p an, daß es sich um eine Pausenkennungsgröße handelt.

45

$$\hat{mp} = \frac{1}{I} \sum_{i=0}^{I-1} Z(i) \quad (7)$$

50

Aufgelöst ergibt dies:

55

$$\hat{mp} = \frac{1}{I} \begin{pmatrix} \sum_{i=0}^{I-1} ZCR(i) \\ \sum_{i=0}^{I-1} BMW(i) \end{pmatrix} \quad (8)$$

60

Zur Abkürzung werden die Variablen mw1 und mw2 eingeführt die entsprechend verwendet werden.

65

$$\hat{\underline{m}}_p = \begin{pmatrix} mw1 \\ mw2 \end{pmatrix} \quad (9)$$

Aus diesen Schätzwerten wird eine Kovarianzmatrix $\hat{\underline{S}}_p$ gebildet. Die Elemente der Kovarianzmatrix geben die mittlere quadratische Abweichung der Merkmale von dem Mittelwert und die statistische Abhängigkeit zwischen den Abweichungen der Merkmale von ihren Mittelwerten an.

Die Kovarianzmatrix läßt sich wie folgt bestimmen (10) und ergibt aufgelöst:

$$\hat{\underline{S}}_p = \frac{1}{I-1} \sum_{i=0}^{I-1} (\underline{c}(i) - \hat{\underline{m}}_p)(\underline{c}(i) - \hat{\underline{m}}_p)^T \quad (10)$$

$$\hat{\underline{S}}_p = \frac{1}{I-1} \sum_{i=0}^{I-1} \begin{pmatrix} ZCR(i) - mw1 \\ BMW(i) - mw2 \end{pmatrix} \begin{pmatrix} (ZCR(i) - mw1) & (BMW(i) - mw2) \end{pmatrix} \quad (11)$$

Mit den eingeführten Variablen DIFM1 und DIFM2 läßt sich schreiben:

$$\hat{\underline{S}}_p = \frac{1}{I-1} \sum_{i=0}^{I-1} \begin{pmatrix} DIFM1 \\ DIFM2 \end{pmatrix} \begin{pmatrix} DIFM1 & DIFM2 \end{pmatrix} \quad (12)$$

$$\hat{\underline{S}}_p = \frac{1}{I-1} \sum_{i=0}^{I-1} \begin{pmatrix} DIFM1^2 & (DIFM1 \cdot DIFM2) \\ (DIFM1 \cdot DIFM2) & DIFM2^2 \end{pmatrix} \quad (13)$$

Eingesetzt werden nun die Matrixelemente S_{11} , S_{12} , S_{21} und S_{22} , die dann aufgelöst ergeben:

$$\hat{S}_p = \frac{1}{I-1} \begin{pmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{pmatrix} \quad (14)$$

$$S_{11} = \sum_{i=0}^{I-1} \text{DIFM1}^2 = \sum_{i=0}^{I-1} (ZCR(i) - mw1)^2 \quad (15)$$

$$S_{22} = \sum_{i=0}^{I-1} \text{DIFM2}^2 = \sum_{i=0}^{I-1} (BMW(i) - mw2)^2 \quad (16)$$

$$S_{12} = \sum_{i=0}^{I-1} \text{DIFM1} \cdot \text{DIFM2} = \sum_{i=0}^{I-1} (ZCR(i) - mw1) \cdot (BMW(i) - mw2) \quad (17)$$

Es gilt: $S_{12} = S_{21}$ Die inverse Kovarianzmatrix \underline{SP}^{-1} ist:

$$\hat{S}_p^{-1} = \frac{I-1}{DET} \begin{pmatrix} S_{22} & -S_{12} \\ -S_{12} & S_{11} \end{pmatrix} \quad (18)$$

mit der Determinanten DET

$$\begin{aligned} DET &= S_{22} \cdot S_{11} - [(-S_{12}) \cdot (-S_{12})] \\ DET &= S_{22} \cdot S_{11} - S_{12}^2 \quad (19) \end{aligned}$$

Somit ergibt sich:

$$\hat{S}_p^{-1} = \begin{pmatrix} \frac{S_{22} \cdot (I-1)}{DET} & \frac{-S_{12} \cdot (I-1)}{DET} \\ \frac{-S_{12} \cdot (I-1)}{DET} & \frac{S_{11} \cdot (I-1)}{DET} \end{pmatrix} \quad (20)$$

$$\hat{S}_p^{-1} = \frac{I-1}{DET} \begin{pmatrix} S'_{22} & -S'_{12} \\ -S'_{12} & S'_{11} \end{pmatrix} \quad (21)$$

Aus den vorangegangenen Berechnungen wird nun eine Prüfgröße u bestimmt, die ein Maß für die Abweichung des aktuellen Merkmalsvektor $c(i)$ vom Pausenmittelwert \underline{mp} . Zur Bestimmung der Prüfgröße u , muß die Mahalanobisdistanz bestimmt werden. Daraus ergibt sich

$$U = \frac{I \cdot (I-N)}{N \cdot (I^2-1)} \left[\begin{array}{c} \underline{\varepsilon}(i) - \hat{\underline{m}}_P \end{array} \right]^T \cdot \hat{\underline{S}}_P^{-1} \cdot \left[\begin{array}{c} \underline{\varepsilon}(i) - \hat{\underline{m}}_P \end{array} \right] \quad (22)$$

mit $Z = (ZRC(i) - mw1)$
 und $P = (BMW(i) - mw2)$
 Und:

$$U = \frac{I \cdot (I-N)}{N \cdot (I^2-1)} \left[\begin{array}{cc} Z & P \end{array} \right] \cdot \hat{\underline{S}}_P^{-1} \cdot \left[\begin{array}{c} Z \\ P \end{array} \right] \quad (23)$$

$$U = \frac{I \cdot (I-N)}{N \cdot (I^2-1)} \left[\begin{array}{cc} Z & P \end{array} \right] \left[\begin{array}{cc} S'_{22} \cdot Z & -(S'_{12} \cdot P) \\ -(S'_{12} \cdot Z) & S'_{11} \cdot P \end{array} \right] \quad (24)$$

$$PREF = \frac{I \cdot (I-N)}{N \cdot (I^2-1)}$$

$$U = PREF \cdot (S'_{22} \cdot Z^2 - S'_{12} \cdot P \cdot Z) + (S'_{11} \cdot P^2 - S'_{12} \cdot P \cdot Z)$$

$$U = PREF \cdot [(S'_{22} \cdot Z^2) - (2 \cdot S'_{12} \cdot P \cdot Z) + (S'_{11} \cdot P^2)]$$

$$U = \frac{PREF \cdot (I-1)}{DET} \left[\begin{array}{c} (S_{22} \cdot Z^2) - (2 \cdot S_{12} \cdot P \cdot Z) + (S_{11} \cdot P^2) \end{array} \right] \quad (25)$$

Mittels dieser Prüfgröße u , kann durch einen Vergleich mit einer festgelegten Schwelle bestimmt werden, ob es sich um Sprache handelt oder nicht. Ist z. B. die Prüfgröße u größer als die Schwelle, handelt es sich um Sprache, falls nicht, handelt es sich um eine Sprachpause. Die Adaption der Schwelle ist zuvor mittels der Signalenergie vorgenommen worden.

Um den Pausendetektor zu initialisieren, werden die ersten I , hier $I = 16$, Blöcke als Sprachpause betrachtet, um $I = 16$ Merkmalsvektoren der Merkmalsstatistik zugrunde legen zu können. Mit dem darauffolgenden Block beginnt die eigentliche Start-/Endpunkt-Detektion.

Für den hier gewählten Fall von $I = 16$ Blöcken und einer Blocklänge von 20 ms dauert die Initialisierung 0,32 Sekunden.

Die zuvor berechnete Prüfgröße u bestimmt sich über die sogenannte Mahalanobisdistanz, die den folgenden Teil der Prüfgröße darstellt.

$$\left[\begin{array}{c} \underline{\varepsilon}(i) - \hat{\underline{m}}_P \end{array} \right]^T \cdot \hat{\underline{S}}_P^{-1} \cdot \left[\begin{array}{c} \underline{\varepsilon}(i) - \hat{\underline{m}}_P \end{array} \right] \quad (26)$$

Diese Mahalanobisdistanz wird für den Vergleich mit einer Schwelle zwischen Sprache und Sprachpause verwendet.

Im folgenden wird das Verfahren nach Anspruch 6 anhand eines Ausführungsbeispiels näher erläutert.

Auch in dem hier vorliegenden Ausführungsbeispiel wird ein Eingangssignal in Blöcke von beispielsweise 20 ms Länge unterteilt. Innerhalb eines Blocks werden beispielsweise $L = 160$ Abtastwerte bestimmt. Für jeden Block werden vorzugsweise $K = 10$ LPC (Linear-Predictive-Coding)-Cepstrum-Koeffizienten errechnet. Hierbei soll der Wert $K = 10$ keineswegs eine Beschränkung darstellen, denn ein Wert größer oder kleiner als 10 ist ebenfalls wählbar. Im folgenden werden die LPC-Cepstrum-Koeffizienten mit $CEP(k, i)$ bezeichnet, wobei $k = 0, 1 \dots K-1$ ist, und i die fortlaufende Anzahl eines Blocks bezeichnet.

Zur Start-/Endpunkt-Detektion zur Worterkennung wird ein aktueller Merkmalsvektor aus mindestens zwei Merkmalen gebildet. Ein erstes aktuelles Merkmal ist eine Funktion der Signalenergie und bestimmt sich zu

$$MV(i) = - \sum_{n=0}^{L-1} |PCM(i, n)|, \quad (27)$$

wobei $PCM(n)$ Puls-Code-modulierte Daten des Eingangssignales sind.

Beide Merkmale, sowohl $MV(m)$ als auch $CEP(k, i)$ sind für den Fall, daß der vorliegende Block eine Sprachpause enthält, einander sehr ähnlich. Die beiden Merkmale sollten aber, damit das mindestens eine weitere Merkmal eine Verbesserung der Start-/Endpunkt-Detektion mit sich bringt, somit also auch zu einer höheren Worterkennungsrate führt, einen signifikanten Unterschied darstellen. Dazu dient folgende Vorgehensweise.

Für den ersten Block mit der Ordnungszahl $i = 0$ werden die Werte $CEPs(k, 0)$ und $MVs(0)$ bestimmt. Der Wert $CEPs(k, i)$ für den nächsten Block berechnet sich dann zu:

$$CEPs(k, i) = - \frac{3}{4} CEPs(k, i-1) + \frac{1}{4} CEPs(k, i). \quad (28)$$

Für jeden aktuellen Block i ergibt sich die cepstrale Differenz zu

$$CD(i) = \sum_{k=0}^{K-1} [CEP(k, i) - CEPs(k, i)]^2. \quad (29)$$

In einem Speicher werden $N = 16$ cepstrale Differenzen der letzten zurückliegenden Blöcke gespeichert. Ebenfalls werden in diesem Speicher die letzten $N = 16$ Energiewerte $MV(i)$ gespeichert. Zur Initialisierung des Start-/Endpunkt-Detektors werden also $N = 16$ Blöcke benötigt. Für jeden folgenden aktuellen Block ist das System in der Lage eine Start-/Endpunkt-Detektion durchzuführen. Eine mittlere cepstrale Distanz $CD_L(i)$ wird über alle $N = 16$ cepstralen Distanzen gemittelt

$$CD_L(i) = \frac{1}{N} \sum_{n=0}^{N-1} CD(i-n) \quad (30)$$

Daraus ergibt sich die Verteilung $\Delta CD(i)$ der letzten $N = 16$ cepstralen Distanzen $CD(i)$ zu:

$$\Delta CD(i) = \frac{1}{N-1} \sum_{n=0}^{N-1} [CD(i-n) - CD_L(i)]^2. \quad (31)$$

Die Energiedifferenz ergibt sich zu:

$$\Delta MV(i) = \frac{1}{N-1} \sum_{n=0}^{N-1} [MV(i-n) - MV_L(i)]^2 \quad (32)$$

woraus sich ebenfalls eine mittlere Energiedifferenz, gebildet über die letzten $N = 16$ Blöcke, folgendermaßen ergibt.

$$MV_L(i) = \frac{1}{N} \sum_{n=0}^{N-1} MV(i-n) \quad (33)$$

Daraus ergibt sich folgendes Resultat.

Für ein fast gleichbleibendes Signal, sind die Verteilungsfunktionen $\Delta MV(i)$ und $\Delta CD(i)$ sehr klein, insbesondere für den Fall daß eine Sprachpause auftritt. Für Sprache werden die Verteilungsfunktionen einen größeren Wert ergeben. Daraus ergibt sich die Bildung einer Maximumfunktion

$$DMAX(i) = \max \{ \Delta CD(i), \Delta MV(i) \} \quad (34).$$

Folgende Fallunterscheidung kann vorgenommen werden:

Für den Fall, daß $DMAX(i)$ größer als ein bestimmter Wert ist, ist das detektierte Signal Sprache. Unterhalb des Wertes ist das detektierte Signal eine Sprachpause.

Bei Verwendung dieser Methode zeigt sich, daß auch beim Auftreten von unterschiedlichen lauten und wechselnden Hintergrundgeräuschen, sich beide Verteilungswerte zwar erhöhen, sich aber bald wieder auf einen niedrigeren Wert einpendeln.

Im folgenden wird anhand von Fig. 1 ein Ausführungsbeispiel gemäß Patentanspruch 1 näher erläutert.

Hierbei wird vorausgesetzt, daß die Anzahl der Merkmale für den Merkmalsvektor gleich $N = 2$ sind, daß die Anzahl der Abtastwerte 160 ist, und daß die Anzahl der in einem Speicher gespeicherten Werte gleich $I = 16$ ist. Vorausgesetzt wird hierbei ebenfalls, daß das vorliegende Sprachsignal in Blöcke aufgeteilt ist. In einem ersten Schritt I werden die Eingangsdaten eingelesen, also die LPC-Cepstrum Koeffizienten eines aktuellen Blockes werden eingelesen und die Abtastwerte der Signalenergie werden eingelesen. In einem zweiten Schritt II werden die Merkmale eines aktuellen Blockes i berechnet, die in diesem Ausführungsbeispiel die cepstrale Distanz und der Betragsmittelwert sind. In einem ersten Entscheidungsglied EI wird ermittelt, ob die fortlaufende Blockzahl eines aktuellen Blockes größer als 1 ist. In diesem Fall entspricht $I = 16$.

Für den Fall, daß i nicht größer als I ist, die Entscheidung von EI also nein lautet, wird folgender Weg zur Initialisierung des Merkmalspeichers eingelegt. In einem dritten Schritt III wird festgelegt, daß der aktuelle Block i eine Sprachpause darstellt. In einem vierten Schritt IV werden die Merkmale in einen Merkmalspeicher eingeschrieben. In einem darauffolgenden zweiten Entscheidungsglied EII wird festgestellt, ob der aktuelle Block $i = 1$ ist. Für den Fall das i ungleich 1 ist, die Entscheidung von EII also nein lautet, ist ein erster Ablauf beendet ENDE und der Ablauf kann erneut mit dem Schritt I für einen nächsten Block beginnen. Für den Fall das der aktuelle Block $i = 1$ ist, wird in einem fünften Schritt V eine Kovarianzmatrix und deren Determinante berechnet. Darauf ist ebenfalls ein erster Ablauf beendet ENDE.

Für den Fall, daß in dem ersten Entscheidungsglied EI der aktuelle Block i größer als 1 ist, die Entscheidung von EI also ja lautet, wird in einem sechsten Schritt VI eine Prüfgröße u gebildet, indem eine Mahalanobisdistanz berechnet wird. In einem siebten Schritt VII wird die Prüfgröße u mit einer Schwelle verglichen, anhand deren festgestellt werden kann, ob eine Sprachpause oder Sprache vorliegt. In einem dritten Entscheidungsglied EIII wird festgestellt, ob eine Sprachpause vorliegt oder nicht. Für den Fall, daß keine Sprachpause vorliegt, die Entscheidung also nein lautet, wird in einem achten Schritt VIII vermerkt, daß sich in dem aktuellen Block Sprache befindet.

Damit ist ebenfalls ein Ablauf beendet ENDE. Für den Fall, daß eine Sprachpause in dem dritten Entscheidungsglied EIII vorliegt, die Entscheidung also ja lautet, wird in einem neunten Schritt IX vermerkt, daß eine Sprachpause vorliegt. Ebenfalls wird der mittlere Merkmalsvektor mit Hilfe des aktuellen Merkmalsvektors aktualisiert. In einem zehnten Schritt X wird eine Kovarianzmatrix und Determinante berechnet. Damit ist ebenfalls ein Ablauf beendet ENDE.

Im folgenden wird anhand von Fig. 2 ein Verfahren zur Start-/Endpunkt-Detektion zur Worterkennung anhand von Fig. 2 eingehend erläutert.

In einem ersten Schritt 1 werden die Daten der Eingangssignale eingelesen. In diesem Fall können dies beispielsweise LPC-Cepstrum Koeffizienten sein und eine mittlere Signalenergie eines aktuellen Blocks. In einem zweiten Schritt 2 wird sowohl eine Verteilung der LPC-Cepstrum Koeffizienten berechnet, als auch eine Verteilung der Signalenergie, jeweils für die letzten 16 Blöcke berechnet. Desweiteren wird eine Maximumfunktion $DMAX$ gebildet, die sich aus dem Maximum der LPC-Cepstrum Verteilungsfunktion und der mittleren Signalenergieverteilungsfunktion zusammensetzt. In einem folgenden ersten Entscheidungsglied E1 wird festgestellt, ob der aktuelle Block einer der ersten 16 Blöcke ist. Für den Fall einer positiven Entscheidung, also ja, wird in einem dritten Schritt 3 festgelegt, daß der letzte Block eine Sprachpause darstellt. Für den Fall einer negativen Entscheidung, also nein, wird in einem zweiten Entscheidungsglied E2 festgestellt, ob der vorangegangene Block Sprache war. Für den Fall, daß in dem letzten Block Sprache vorlag, wird in einem dritten Entscheidungsglied E3 festgestellt, ob die Sprache länger als 2 Sekunden andauert. Für den Fall einer positiven Entscheidung wird in einem vierten Schritt 4 ein Zähler, der die Anzahl der detektierten Endpunkte aufaddiert, zurückgesetzt. Ebenso wird ein Zähler, der die Anzahl der detektierten Startpunkte aufaddiert, zurückgesetzt. Ebenso wird ein Zähler

der die Wortlänge angibt zurückgesetzt. Die darauffolgende Entscheidung ist, daß der aktuelle Block eine Sprachpause darstellt.

Für den Fall einer negativen Entscheidung des dritten Entscheidungsgliedes E3, wird in einem vierten Entscheidungsglied E4 festgestellt, ob die Maximumfunktion DMAX kleiner als eine Schwelle ist. Für den Fall, daß die Maximumfunktion DMAX nicht kleiner als eine Schwelle ist, liegt in dem aktuellen Block Sprache vor. Zuvor wird aber in einem weiteren Schritt 4' der Zähler der die Startpunkte aufaddiert, zurückgesetzt. Ebenso wird der Zähler der die Endpunkte aufaddiert zurückgesetzt. Die Wortlänge aber wird um die Länge des aktuellen Blockes erhöht. Für den Fall das die Maximumfunktion DMAX kleiner als die Schwelle ist, die Entscheidung also ja lautet, wird in einem fünften Schritt 5 der Zähler der die Endpunkte addiert um eins erhöht. In einem weiteren fünften Entscheidungsglied E5 wird festgestellt, ob die aktuelle Zeit der Sprachpause größer als die Zahl der gezählten Endpunkte ist, wobei hierbei die Anzahl der gezählten Endpunkte eine, während einer Sprachpause verstrichenen Zeit repräsentiert. Für den Fall einer negativen Entscheidung wird mit dem zuvor beschriebenen vierten Schritt 4 fortgefahren und die Entscheidung lautet, daß sich in dem Block eine Sprachpause ist. Für den Fall einer positiven Entscheidung des fünften Entscheidungsgliedes E5 wird festgestellt, daß in dem aktuellen Block Sprache befindet.

Ausgehend von dem zweiten Entscheidungsglied E2, indem festgestellt wurde, ob der vorangegangene Block Sprache war, wird für den Fall einer negativen Entscheidung, eine weitere Entscheidung in einem sechsten Entscheidungsglied E6 herbeigeführt. In dem sechsten Entscheidungsglied E6 wird festgestellt, ob die Maximumfunktion DMAX größer als eine Schwelle ist. Für den negativen Fall, also nein, wird in einem sechsten Schritt 6 sowohl der Zähler der die Startpunkte, als auch der Zähler, der die Endpunkte aufaddiert, zurückgesetzt. Im weiteren wird festgestellt, daß sich in diesem aktuellen Block eine Sprachpause befindet.

Für den positiven Fall, also Ja, wird in einem siebten Schritt 7 der Zähler der die Startpunkte zählt um eins erhöht. In einem darauffolgenden siebten Entscheidungsglied E7 wird festgestellt, ob die Zeit des aktuellen Wortes, also der Sprache, größer als die Anzahl der gezählten Startpunkte ist. Für ein positives Resultat wird festgestellt, daß eine Sprachpause vorliegt.

Für ein negatives Resultat wird in einem achten Schritt 8 fortgefahren, der dem vierten Schritt 4 entspricht und alle Zähler zurücksetzt. Die darauffolgende Entscheidung besagt, daß in dem aktuellen Block Sprache vorliegt.

Im folgenden wird auf spezielle Ausgestaltungen der Erfindung näher eingegangen.

Im Bezug auf das Verfahren nach Anspruch 6 läßt sich anmerken, daß bei einer Berechnung der Verteilungsfunktionen eine hohe Genauigkeit der Resultate gewährleistet sein muß. Speziell wenn die Werte sehr klein sind, muß eine hohe Genauigkeit bis auf mehrere Stellen hinter dem Komma gegeben sein. Um diese Empfindlichkeit aber zu verringern, kann vorzugsweise ein Logarithmus zur Basis 2 der Verteilungsfunktionen gebildet werden.

Hierbei wird eine Funktion gemäß:

$$\Delta LCD(i) = \log_2(\Delta CD(i)) \quad (35)$$

und eine Funktion gemäß

$$\Delta LED(i) = \log_2(\Delta ED(m)) \quad (36)$$

gebildet. Bemerkt werden soll hier, daß $\Delta LCD(i)$ und ΔLED aus einem Intervall (0,31) bestimmt werden. Zur Bestimmung ob Sprache oder ob eine Sprachpause vorliegt, wird eine Maximumfunktion gemäß

$$\Delta DMAX(i) = \max \{ \Delta LCD(i), \Delta LED(i) \} \quad (37)$$

berechnet. Danach wird ein Vergleich mit einer Schwelle durchgeführt, aufgrund derer eine Fallunterscheidung vorgenommen wird.

Für den Fall, daß

$$\Delta DMAX(i) < \text{Schwelle}$$

ist, folgt:

daß in dem Block eine Sprachpause vorliegt.
Für den Fall, daß

$$\Delta DMAX(i) > \text{Schwelle ist,}$$

folgt:

daß in dem Block Sprache vorliegt.
Für den Fall, daß

$$\Delta DMAX(i) = \text{Schwelle}$$

ist, folgt:

daß in dem Block entweder Sprache oder eine Sprachpause vorliegt, entsprechend dem, was bisher in dem Block detektiert worden ist.

Diese Fallunterscheidung gilt nicht ausschließlich, insbesondere weil einige Hinweise auf eine gegenteilige

Entscheidung gegeben sein können (siehe Beschreibung zu Fig. 2). Hierbei soll noch bemerkt werden, daß die Schwelle konstant bleibt, und unabhängig von der Lautstärke der Hintergrundgeräusche ist. Demnach ist eine Adaptation für ein Verfahren gemäß Patentanspruch 6 bis 8 nicht nötig. Besonders geeignet ist dieses Verfahren auch für Spracherkennung z. B. in einem fahrenden PKW, usw.

5 Bei den Verfahren gemäß Patentanspruch 1 bis 5 bleibt anzumerken, daß eine höhere Bewertung eines der Merkmale für den Merkmalsvektor, für das Verfahren vorteilhaft sein kann, entsprechend den Umgebungsgeräuschen. Ebenso können zusätzliche Glättungsmechanismen eingesetzt werden.

Bei allen vorab erläuterten Verfahren gilt, daß es sich um Echtzeit-Implementierungen handelt.

Patentansprüche

10 1. Verfahren zur Start-/Endpunkt-Detektion zur Erkennung von Worten in einem Sprachsignal, wobei ein detektierter Startpunkt einen Anfang von Sprache und gleichzeitig ein Ende einer Sprachpause, und ein detektierter Endpunkt ein Ende von Sprache und gleichzeitig einen Anfang einer Sprachpause angibt,

15 — bei dem eine blockweise Unterteilung des Sprachsignales vorgenommen wird,
 — bei dem ein aktueller Merkmalsvektor aus mindestens zwei aktuellen Merkmalen gebildet wird, von denen ein erstes aktuelles Merkmal eine Funktion der Signalenergie ist, und von denen das mindestens eine weitere aktuelle Merkmal eine Funktion der quadratischen Differenz eines LPC (Linear-Predictive-Coding)-Cepstrum-Koeffizienten eines aktuellen Blocks gegenüber einem mittleren LPC-Cepstrum-Koeffizienten ist,

20 — bei dem ein mittlerer Merkmalsvektor berechnet wird, der aus einer fest definierten Anzahl I von Blöcken, in denen eine Sprachpause vorliegt, berechnet wird, und der mit jeder neuen, aktuell auftretenden Sprachpause aktualisiert wird,

25 — und bei dem mittels des aktuellen Merkmalsvektors und des mittleren Merkmalsvektors eine Prüfgröße u ermittelt wird, die, verglichen mit einem Schwellwert, eine Aussage darüber liefert, ob eine Sprachpause oder ob Sprache vorliegt und damit die Start- und Endpunkte detektiert.

2. Verfahren nach Anspruch 1, bei dem der aktuelle Merkmalsvektor c(i) aus mindestens zwei aktuellen Merkmalen gebildet wird,

$$c(i) = \begin{bmatrix} ZCR(i) \\ BMW(i) \end{bmatrix}$$

35 von denen ein erstes aktuelles Merkmal BMW(i) eine Funktion der Signalenergie ist

$$BMW(i) = \frac{1}{L} \sum_{k=0}^{L-1} |x(k,i)|$$

40 von denen das mindestens eine weitere aktuelle Merkmal eine Funktion der quadratischen Differenz der aktuellen LPC-Cepstrum-Koeffizienten gegenüber dem mittleren LPC-Cepstrum-Koeffizienten ist

$$ZCR(i) = \sum_{n=0}^{K-1} [CEP(n,i) - CEP_{\text{AVER}}(n)]^2$$

50 und bei dem ein mittlerer Merkmalsvektor berechnet wird

$$\hat{m}_p = \frac{1}{I} \sum_{i=0}^{I-1} c(i)$$

60 mittels dem eine Kovarianzmatrix berechnet wird, die zur Bestimmung der Prüfgröße u herangezogen wird

$$U = \frac{I \cdot (I-N)}{N \cdot (I^2-1)} \left(c(i) - \hat{m}_p \right)^T \cdot \hat{S}_P^{-1} \cdot \left(c(i) - \hat{m}_p \right)$$

die eine Aussage darüber liefert, ob eine Sprachpause oder ob Sprache vorliegt.

3. Verfahren nach Anspruch 1 oder 2, bei der die ermittelte Prüfgröße u anhand einer Berechnung einer Mahalanobisdistanz, bestimmt wird.

4. Verfahren nach einem der Ansprüche 1 bis 3, bei dem das mindestens eine weitere aktuelle Merkmal im Vergleich zu dem ersten aktuellen Merkmal unterschiedlich gewichtet wird.

5. Verfahren nach einem der vorgehenden Ansprüche, bei dem in Abhängigkeit von einem Umgebungsgeräuschpegel Glättungsmechanismen und/oder adaptive Ein- und Ausschalteschwellen eingesetzt werden.

6. Verfahren zur Start-/Endpunkt-Detektion, zur Erkennung von Worten in einem Sprachsignal,
 – bei dem eine blockweise Unterteilung des Sprachsignales vorgenommen wird,
 – bei dem ein aktueller Merkmalsvektor aus mindestens zwei aktuellen Merkmalen gebildet wird, von denen ein erstes aktuelles Merkmal eine Funktion der Signalenergie ist, und bei dem das mindestens eine weitere aktuelle Merkmal eine Funktion der LPC (Linear-Predictive-Coding)-Cepstrum-Koeffizienten ist,

– bei dem mittels der Funktionen der aktuellen Merkmale Verteilungsfunktionen errechnet werden, und

– bei dem eine Maximumfunktion DMAX der Verteilungsfunktionen ein Maß dafür ist, ob zwischen den detektierten Start-/Endpunkten eine Sprachpause oder Sprache auftritt.

7. Verfahren nach Anspruch 6, bei dem das erste aktuelle Merkmal eine Funktion der Signalenergie ist, mit

$$MV(i) = \frac{1}{L} \sum_{n=0}^{L-1} |PCM(i, n)|$$

und das mindestens eine weitere Merkmal eine Funktion der LPC-Cepstrum Koeffizienten entsprechend

$$CD(i) = \sum_{k=0}^{K-1} [CEP(k, i) - CEPs(k, i)]^2 \text{ ist,}$$

wobei $CEPs(k, i)$ einem Kurzzeitmittelwert entspricht, und bei dem Verteilungsfunktionen

$$\Delta CD(i) = \frac{1}{N-1} \sum_{n=0}^{N-1} [CD(i-n) - CD_L(i)]^2 \text{ und}$$

$$\Delta MV(i) = \frac{1}{N-1} \sum_{n=0}^{N-1} [MV(i-n) - MV_L(i)]^2$$

$$\text{mit } CD_L(i) = \frac{1}{N} \sum_{n=0}^{N-1} CD(i-n)$$

$$MV_L(i) = \frac{1}{N} \sum_{n=0}^{N-1} MV(i-n)$$

zur Bestimmung der Maximumfunktion

$$D_{MAX}(i) = \max \{ \Delta CD(i), \Delta MV(i) \}$$

verwendet werden.

8. Verfahren nach Anspruch 7 oder 8, bei dem logarithmische Verteilungsfunktionen ΔLCD und ΔLMV entsprechend:

$$\Delta LCD(i) = \log_2(\Delta CD(i)) \text{ und}$$

$$\Delta LMV(i) = \log_2(\Delta MV(i))$$

zu einer Bestimmung einer Maximumfunktion ΔD_{MAX} verwendet werden, entsprechend

$$\Delta D_{MAX}(i) = \max \{ \Delta LCD(i), \Delta LMV(i) \}$$

um festzustellen, ob eine Sprachpause oder ob Sprache vorliegt.

Hierzu 2 Seite(n) Zeichnungen

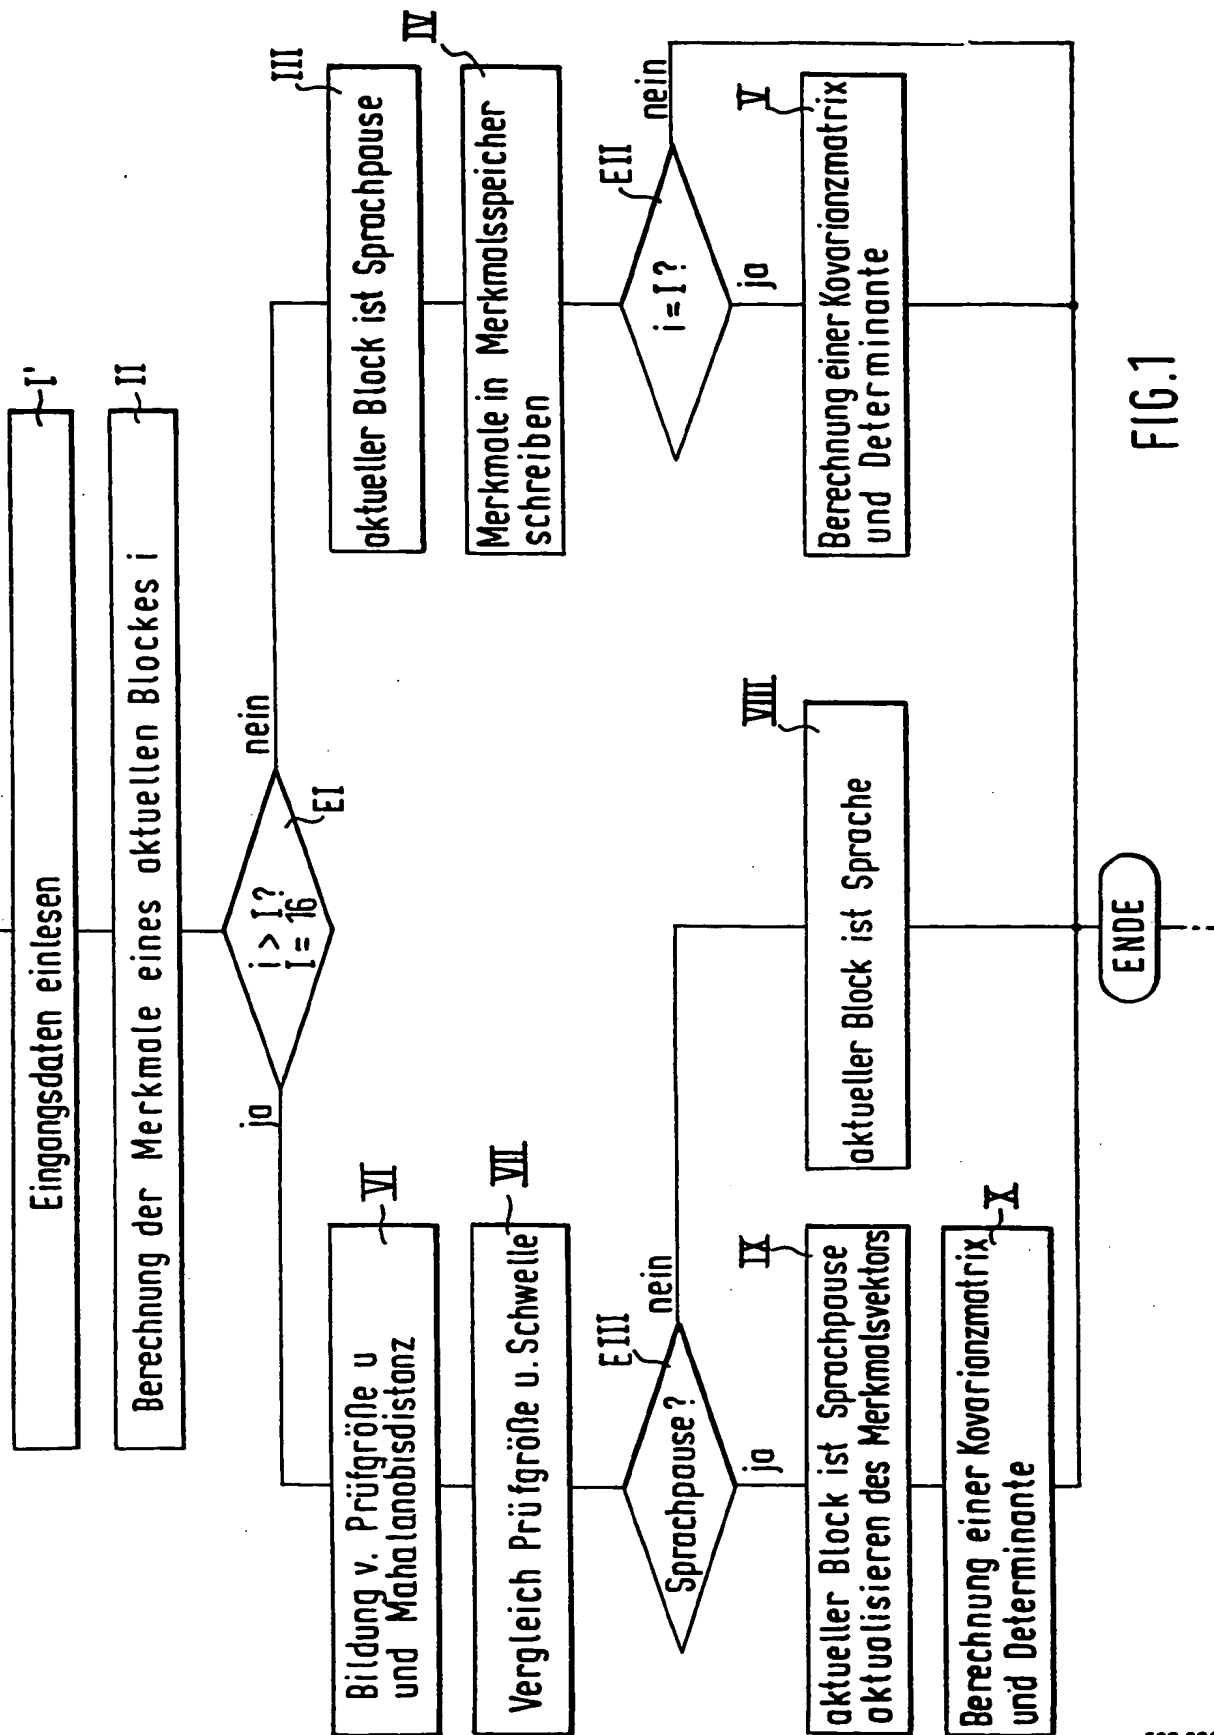


FIG.1

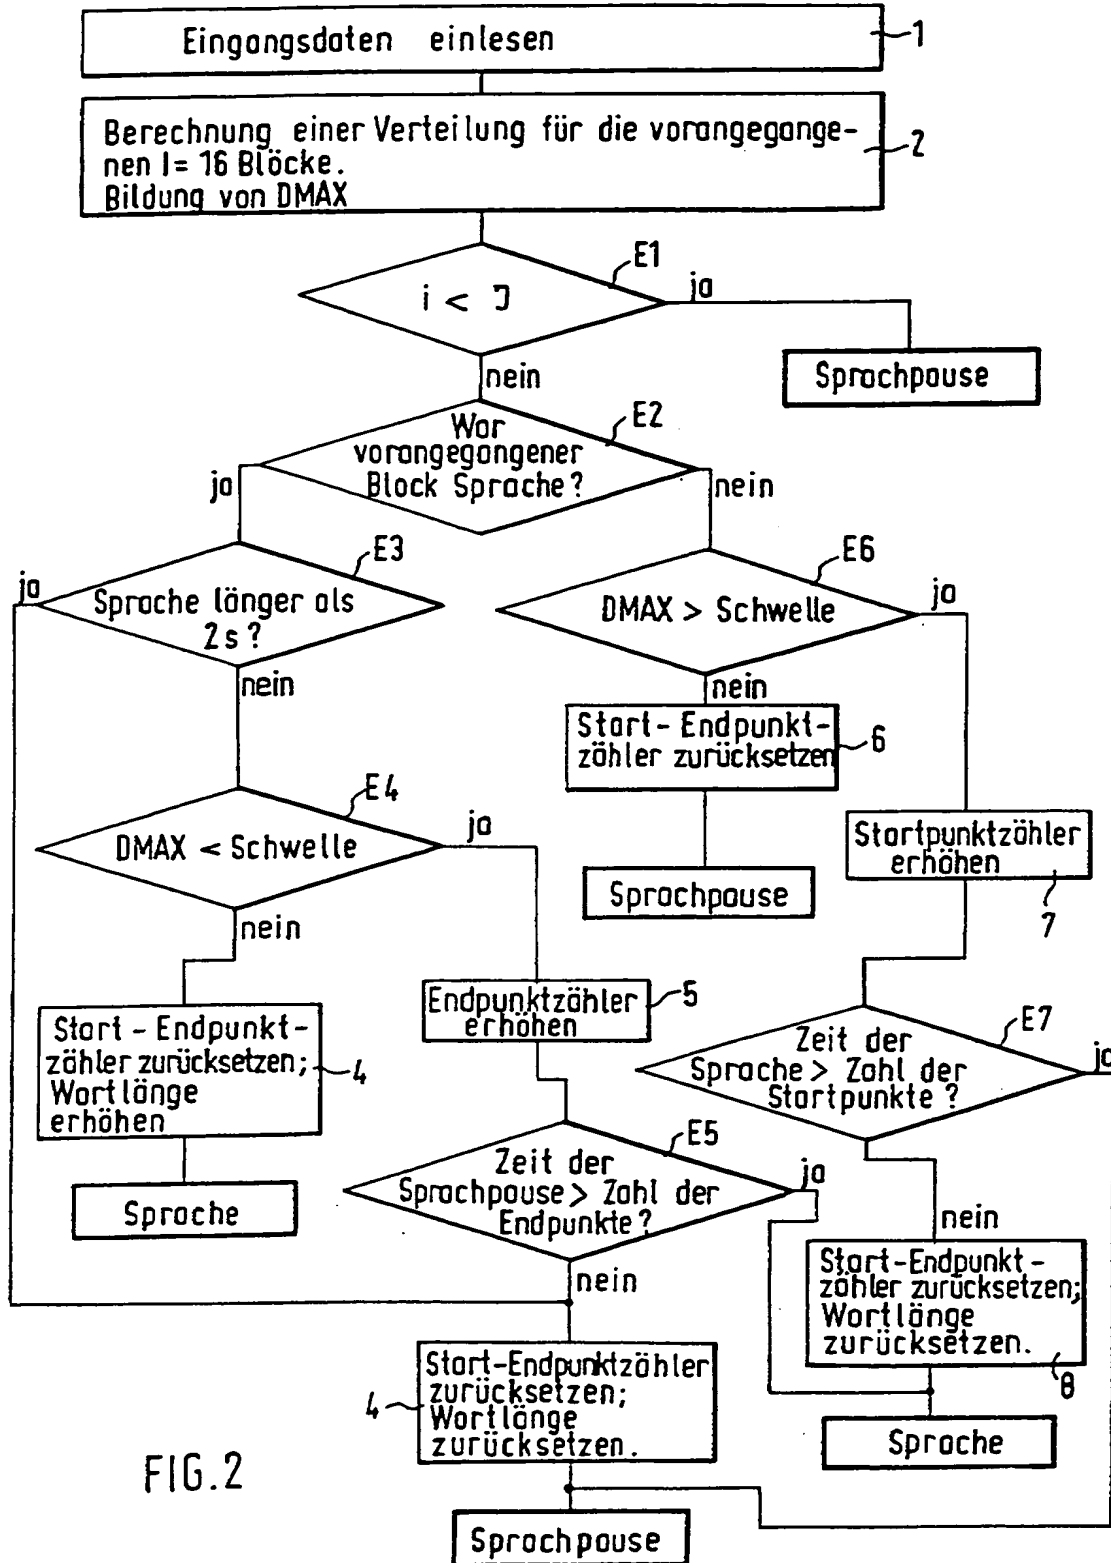


FIG.2